

Algorithmes d'optimisation

5 février 2019

Table des matières

Table des matières	1
1 Existence, unicité, convexité	4
1.1 Existence	5
1.2 Condition nécessaire d'optimalité	6
1.3 Convexité et condition suffisante d'optimalité	6
1.4 Stricte convexité et unicité du minimiseur	8
2 Descente de gradient à pas optimal	9
2.1 Méthode de descente	9
2.2 Convexité et hessienne	10
2.3 Descente de gradient à pas optimal	12
3 Descente de gradient à pas optimal II	15
3.1 Forte convexité et stabilité du minimum	15
3.2 Vitesse de convergence du gradient à pas optimal	17
3.3 Une condition suffisante pour la forte convexité	18
4 Descente avec pas d'Armijo	20
4.1 Choix du pas par rebroussement	20

Introduction

Motivation Dans de nombreuses applications, la formulation naturelle du problème qu'on cherche à résoudre est un problème d'optimisation :

- Dans la méthode des moindres carrés, on remplace un système linéaire $Ax = b$ surdéterminé et/ou n'ayant pas de solution (par exemple car certaines des égalités se contredisent) par le problème d'optimisation suivant :

$$\min_{x \in \mathbb{R}^N} \|Ax - b\|^2. \quad (1)$$

Le minimiseur x^* de ce problème vérifie “au mieux” la famille d'équation $Ax = b$. Au contraire, lorsqu'un système linéaire $Ax = b$ admet plusieurs solutions, on peut en sélectionner une en considérant le problème

$$\min_{x \in K} \|x\|^2 \quad K = \{x \in \mathbb{R}^N \mid Ax = b\} \quad (2)$$

- Si $\bar{x} \in \mathbb{R}^N$ représente un signal 1D échantillonné avec du bruit (\bar{x}_i représentant par exemple la mesure effectuée en un temps t_i), on peut débruiter le signal en considérant le problème d'optimisation suivant, où $\lambda > 0$ est un paramètre :

$$\min_{x \in \mathbb{R}^N} \|x - \bar{x}\|^2 + \lambda \sum_{1 \leq i \leq N-1} |x_{i+1} - x_i|^2 \quad (3)$$

un compromis entre deux comportements : x^* doit être proche de \bar{x} (c'est le rôle du premier terme $\|x - \bar{x}\|^2$ de la fonction optimisée) mais doit également être “régulier”, au sens où deux valeurs successives x_i et x_{i+1} doivent être proches (second terme $\sum_i |x_{i+1} - x_i|^2$).

- En finance, on peut considérer le problème de l'optimisation de portefeuille. Étant donné N actifs, il s'agit de déterminer le pourcentage $x_i \geq 0$ du portefeuille que l'on investit dans l'actif i . Comme on souhaite investir 100% du portefeuille, ce problème d'optimisation est accompagné d'une contrainte $\sum_{1 \leq i \leq N} x_i = 1$. On pourra donc considérer des problèmes d'optimisation *avec contraintes* de la forme

$$\min_{x \in \Delta} f(x) \quad \text{où } \Delta = \{x \in \mathbb{R}^N \mid \forall i, x_i \geq 0 \text{ et } \sum_i x_i = 1\}. \quad (4)$$

La fonction f est typiquement de la forme $f(x) = \frac{1}{\varepsilon} |\langle c|x \rangle - r|^2 + \langle x|Qx \rangle$: $c \in \mathbb{R}^N$ représente le rendement des actifs et le premier terme cherche à fixer

le niveau de rendement $\langle c|x \rangle = \sum_i c_i x_i$ à r . Le second terme de la fonction $\langle x|Qx \rangle$ est une mesure de risque : Q est une matrice symétrique mesurant les corrélations entre actifs, et on cherche un investissement minimisant cette corrélation.

- En apprentissage automatique (*machine learning*), de nombreux problèmes peuvent être formulés comme des problèmes d'optimisation. Nous verrons par exemple des problèmes de classification, que l'on résoudra par régression logistique ou par machine à vecteurs support (*support vector machine*).

Pour plus d'exemple, on renvoie au livre de Boyd et Vanderberghe, qui est disponible gratuitement (en anglais) en ligne : <http://web.stanford.edu/~boyd/cvxbook/>.

Problèmes avec/sans contrainte On peut séparer les problèmes en deux grandes classes. Il y a d'une part les problèmes d'optimisation sans contraintes, où l'on cherche à minimiser une fonctionnelle sur \mathbb{R}^d ou sur son domaine de définition *ouvert* (les problèmes (1), (3) et la régression logistique sont de ce type). D'autre part, les problèmes d'optimisation avec contraintes, où l'on cherche à minimiser sur l'ensemble des points de \mathbb{R}^N vérifiant un certain nombre de contraintes d'égalité ou d'inégalité (les problèmes (2), (4) et les machines à vecteurs support sont de ce type).

Convexité Tout les algorithmes et exemples présentés dans ce cours relèvent de l'optimisation *convexe*, où aussi bien la fonction optimisée que le domaine d'optimisation sont supposés convexes. La raison fondamentale pour laquelle on se restreint à ce cas est que pour les problèmes d'optimisation convexe, un minimiseur local est *automatiquement* minimiseur global.

Chapitre 1

Existence, unicité, convexité

Contents

1.1	Existence	5
1.2	Condition nécessaire d'optimalité	6
1.3	Convexité et condition suffisante d'optimalité	6
1.4	Stricte convexité et unicité du minimiseur	8

Dans cette première partie, on s'intéresse à un problème de minimisation d'une fonction $f \in \mathcal{C}^1(\Omega)$ où Ω est un ouvert de \mathbb{R}^d :

$$\inf_{x \in \Omega} f(x) \tag{P}$$

Définition 1. On appelle :

- (i) *infimum* de (P) la valeur $\inf_{\Omega} f$.
- (ii) *minimiseur global* (ou simplement minimiseur) de (P) tout élément $x^* \in \Omega$ vérifiant $f(x^*) = \inf_{\Omega} f$. On note $\arg \min_{\Omega} f$ l'ensemble des minimiseurs de f (qui peut être vide).
- (iii) On appelle *suite minimisante* pour (P) toute suite $x^{(0)}, \dots, x^{(k)}, \dots$ d'éléments de Ω telle que $\lim_{k \rightarrow +\infty} f(x^{(k)}) = \inf_{x \in \Omega} f(x)$.

Remarque 1. Il est possible que le problème (P) n'admette pas de minimiseur : penser par exemple à $f(x) = \exp(x)$ sur $\Omega = \mathbb{R}$, ou $f(x) = x^2$ sur $\Omega =]0, +\infty[$.

Lemme 1. *Il existe une suite minimisante pour le problème (P).*

Démonstration. Par définition de l'infimum, pour tout $k > 0$, il existe un élément $x^{(k)} \in \Omega$ tel que $\inf_{\Omega} f \leq f(x^{(k)}) \leq \inf_{\Omega} f + \frac{1}{k}$, soit $\lim_{k \rightarrow +\infty} f(x^{(k)}) = \inf_{\Omega} f$. \square

1.1 Existence

Proposition 2. Soit $\Omega \subseteq \mathbb{R}^d$ ouvert et $f \in \mathcal{C}^0(\Omega)$. On suppose de plus qu'il existe $x_0 \in \Omega$ tel que le sous-niveau $S = \{x \in \Omega \mid f(x) \leq f(x_0)\}$ est compact. Alors le problème d'optimisation (P) admet un minimiseur global.

Démonstration. Si $f(x_0) = \inf_{\Omega} f$ on a déjà l'existence d'un minimum, à savoir le point x_0 lui-même. On suppose donc maintenant que $f(x_0) > \inf_{\Omega} f$. Soit $(x^{(k)})_{k \geq 0}$ une suite minimisante, qui vérifie donc $\lim_{k \rightarrow +\infty} f(x^{(k)}) = \inf_{\Omega} f < f(x_0)$. Alors, pour k suffisamment grand, on a $f(x^{(k)}) \leq f(x_0)$, soit $x^{(k)} \in S$. Comme l'ensemble S est compact, on peut extraire une sous-suite $(x^{(\sigma(k))})_{k \geq 0}$ qui converge vers un point $x^\infty \in S \subseteq \Omega$. Alors, par continuité de f et par définition d'une suite minimisante on a $f(x^\infty) = \lim_{k \rightarrow +\infty} f(x^{(\sigma(k))}) = \inf_{\Omega} f$, et x^∞ minimise donc f sur Ω . \square

Corollaire 3. Soit $f \in \mathcal{C}^0(\Omega)$ où $\Omega = \mathbb{R}^d$ et vérifiant la propriété suivante :

$$\forall x \in \mathbb{R}^d, f(x) \geq C \|x\|^p + D,$$

où $C > 0, D \in \mathbb{R}$ et $p > 0$. Alors le problème (P) admet un minimiseur.

Démonstration. Soit $x_0 \in \mathbb{R}^d$ quelconque et $S = \{x \in \mathbb{R}^d \mid f(x) \leq f(x_0)\}$. Pour pouvoir appliquer le théorème précédent, il suffit de démontrer que S est compact. Comme on sait déjà que S est fermé comme sous-niveau d'une fonction continue, il suffit de démontrer que cet ensemble est borné. Or, pour tout $x \in S$, on a

$$C \|x\|^p + D \leq f(x) \leq f(x_0)$$

soit $\|x\|^p \leq E := |f(x_0) - D|/C$. Ainsi, l'ensemble S est contenu dans la boule centrée en 0 et de rayon $\sqrt[p]{E}$ et est donc borné. \square

Corollaire 4. Soit $f \in \mathcal{C}^0(\Omega)$ où $\Omega = \mathbb{R}^d$ vérifiant la propriété suivante¹ : pour toute suite $(x^{(k)})_{k \geq 0}$ vérifiant $\lim_{k \rightarrow +\infty} \|x^{(k)}\| = +\infty$ alors $\lim_{k \rightarrow +\infty} f(x^{(k)}) = +\infty$. Alors (P) admet un minimiseur global.

Démonstration. Soit $x_0 \in \mathbb{R}^d$ quelconque et $S = \{x \in \mathbb{R}^d \mid f(x) \leq f(x_0)\}$. Pour montrer l'existence d'un minimiseur, il suffit de démontrer que S est compact. Par l'absurde supposons S non compact. Comme S est fermé (sous-niveau d'une fonction continue) on en déduit qu'il n'est pas borné. Il existe donc une suite $(x^{(k)})_{k \geq 0}$ d'éléments de S (c'est-à-dire tels que $f(x^{(k)}) \leq f(x_0)$) telle que $\lim_{k \rightarrow +\infty} \|x^{(k)}\| = +\infty$. Ceci contredit notre hypothèse. \square

1. qu'on peut résumer en disant que “ f tend vers l'infini à l'infini”

1.2 Condition nécessaire d'optimalité

Définition 2. Soit $f \in \mathcal{C}^1(\Omega)$, où $\Omega \subseteq \mathbb{R}^d$ est un ouvert. On appelle *gradient* de f en $x_0 \in \Omega$ le vecteur des dérivées partielles, où l'on a noté $(e_i)_{1 \leq i \leq d}$ la base canonique de \mathbb{R}^d :

$$\nabla f(x) = \left(\frac{\partial f}{\partial e_i}(x) \right)_{1 \leq i \leq d} \quad \text{où} \quad \frac{\partial f}{\partial e_i}(x) = \lim_{\varepsilon \rightarrow 0} \frac{1}{\varepsilon} (f(x + \varepsilon e_i) - f(x)).$$

Remarque 2 (Calcul du gradient). Soit $f \in \mathcal{C}^0(\Omega)$ et $x \in \Omega$. On rappelle que si l'on peut écrire un développement limité d'ordre 1 pour f en x , de la forme

$$f(x + v) = f(x) + \langle g | v \rangle + o(\|v\|), \quad (1.1)$$

alors f est différentiable au point x et $\nabla f(x) = g$.

Exemple 1. Considérons $f(x) = \|x\|^2$ sur \mathbb{R}^d . En développant le carré de la norme, on obtient $f(x + v) = \|x\|^2 + \langle 2x | v \rangle + \|v\|^2$, qui est de la forme (1.1) avec $g = 2x$. On en déduit que $\nabla f(x) = 2x$, ce qui est conforme avec le calcul.

Théorème 5 (Fermat). Soit $f \in \mathcal{C}^1(\Omega)$, où $\Omega \subseteq \mathbb{R}^d$ est un ouvert, et x^* un minimiseur de (P). Alors $\nabla f(x^*) = 0$.

Remarque 3. La contraposée est fautive : prendre $f(x) = x^3$ sur $\Omega = \mathbb{R}$: le point 0 vérifie $f'(0) = 0$ mais n'est pas un minimiseur (même local).

Démonstration. Comme Ω est ouvert, il existe $\varepsilon_0 > 0$ tel que $B(x^*, \varepsilon_0) \subseteq \Omega$. Soit $1 \leq i \leq d$ et $\varepsilon \in [-\varepsilon_0, \varepsilon_0]$, de sorte que le point $x^* + \varepsilon e_i$ appartient à Ω . Comme x^* est un minimiseur de f sur Ω on a $f(x^* + \varepsilon e_i) \geq f(x^*)$. Ainsi,

$$\forall 0 < \varepsilon \leq \varepsilon_0, \quad \frac{f(x^* + \varepsilon e_i) - f(x^*)}{\varepsilon} \geq 0.$$

En passant à la limite, on obtient $\frac{\partial f}{\partial e_i}(x^*) \geq 0$. De même, en considérant le cas $\varepsilon < 0$

$$\forall -\varepsilon_0 \leq \varepsilon < 0, \quad \frac{f(x^* + \varepsilon e_i) - f(x^*)}{\varepsilon} \leq 0,$$

d'où l'on tire en passant à la limite $\frac{\partial f}{\partial e_i}(x^*) \leq 0$, soit *in fine* $\frac{\partial f}{\partial e_i}(x^*) = 0$. \square

1.3 Convexité et condition suffisante d'optimalité

Définition 3. Un sous-ensemble X de \mathbb{R}^d est dit *convexe* s'il contient tout segment reliant deux de ses points, c'est-à-dire :

$$\forall (x, y) \in X, \forall t \in [0, 1], (1 - t)x + ty \in X.$$

- Exemple 2.* (a) Pour tout $x \in \mathbb{R}^d$ et $r \geq 0$, la boule centrée en x et de rayon r (ouverte ou fermée) est convexe.
 (b) Pour tout vecteur $v \in \mathbb{R}^d$ et tout $b \in \mathbb{R}$, l'ensemble $\{x \in \mathbb{R}^d \mid \langle x|v \rangle \leq b\}$ est un ensemble convexe, appelé *demi-espace*.
 (c) L'intersection $\bigcap_{i \in I} X_i$ d'une famille quelconque $(X_i)_{i \in I}$ de convexes est convexe.

Définition 4. Soit $X \subseteq \mathbb{R}^d$ convexe. Une fonction $f : X \rightarrow \mathbb{R}$ est *convexe* si

$$\forall (x, y) \in X, \forall t \in [0, 1], f((1-t)x + ty) \leq (1-t)f(x) + tf(y).$$

Exercice 1. Soit $f : \Omega \rightarrow \mathbb{R}$ une fonction convexe. Montrer que l'ensemble

$$\{x \in \Omega \mid f(x) \leq C\}$$

est convexe quel que soit C . En déduire que l'ensemble des minimiseurs de (P) est un ensemble convexe fermé (possiblement vide).

Proposition 6. Soit $f \in \mathcal{C}^1(\Omega)$, $\Omega \subseteq \mathbb{R}^d$ ouvert et $X \subseteq \Omega$ convexe. Alors les propositions suivantes sont équivalentes :

- (i) f est convexe sur X ,
- (ii) $\forall x, y \in X$, la fonction $g : t \in [0, 1] \mapsto f((1-t)x + ty)$ est convexe.
- (iii) $\forall x, y \in X$, $f(y) \geq f(x) + \langle y - x | \nabla f(x) \rangle$,
- (iv) $\forall x, y \in X$, $\langle \nabla f(x) - \nabla f(y) | x - y \rangle \geq 0$.

Lemme 7. Soit $X \subseteq \mathbb{R}^d$ convexe et $f \in \mathcal{C}^1(\Omega)$. Étant donné $x \in \Omega$ et $v \in \mathbb{R}^d$, on définit $x_t = x + tv$ et $g(t) = f(x_t)$. Alors,

$$g'(t) = \langle \nabla f(x_t) | v \rangle. \quad (1.2)$$

Démonstration de la proposition 6. (i) \iff (ii) conséquence directe de la définition.

(ii) \implies (iii). Soit x, y dans X . Si f est convexe, alors la fonction $g : t \mapsto f(x_t)$ où $x_t = (1-t)x + tv = x + t(y-x)$ l'est aussi. Ainsi,

$$g(t) = g((1-t)0 + t1) \leq (1-t)g(0) + tg(1),$$

soit $g(1) \geq g(0) + \frac{1}{t}(g(t) - g(0))$ pour $0 < t \leq 1$. En passant à la limite lorsque $t \rightarrow 0$, on obtient $g(1) \geq g(0) + g'(0)$, soit par le lemme, $f(y) \geq f(x) + \langle y - x | \nabla f(x) \rangle$.

(iii) \implies (ii). Soit $x, y \in X$, $t \in [0, 1]$ et $z = (1-t)x + ty$. Alors, l'inégalité (ii) appliquée à z, x puis z, y donne

$$f(x) \geq f(z) + \langle x - z | \nabla f(z) \rangle = f(z) + t \langle x - y | \nabla f(z) \rangle$$

$$f(y) \geq f(z) + \langle y - z | \nabla f(z) \rangle = f(z) + (1-t) \langle y - x | \nabla f(z) \rangle$$

La somme de $(1-t)$ fois la première inégalité et t fois la seconde donne

$$(1-t)f(x) + tf(y) \geq f(z).$$

(iii) \implies (iv) Il suffit de sommer l'inégalité (iii) et la même inégalité où l'on a inversé le rôle de x et y .

(iv) \implies (iii) Soit encore $g : t \mapsto f(x_t)$ où $x_t = (1-t)x + tv = x + t(y-x)$. Comme $g'(t) = \langle \nabla f(x_t) | y-x \rangle$, (lemme 7) l'inégalité (iv) appliquée en x_s et x_t (où $t > s$) nous donne

$$g'(t) - g'(s) = \langle \nabla f(x_t) - \nabla f(x_s) | y-x \rangle = \frac{1}{t-s} \langle \nabla f(x_t) - \nabla f(x_s) | x_t - x_s \rangle \geq 0,$$

et g' est donc croissante sur $[0, 1]$. Ainsi, $g(1) = g(0) + \int_0^1 g'(t) dt \geq g(0) + g'(0)$, ce qui se traduit par $f(y) \geq f(x) + \langle y-x | \nabla f(x) \rangle$ comme souhaité. \square

Théorème 8. Soit $\Omega \subseteq \mathbb{R}^d$ un ouvert convexe et $f \in \mathcal{C}^1(\Omega)$ convexe. Alors $x^* \in \Omega$ est un minimiseur de (P) si et seulement si $\nabla f(x^*) = 0$.

Démonstration. Le théorème de Fermat nous donne déjà le sens direct. Pour la réciproque, il suffit de remarquer que si $\nabla f(x^*) = 0$, la proposition précédente donne

$$\forall y \in \Omega, f(y) \geq f(x^*) + \langle y-x^* | \nabla f(x^*) \rangle = f(x^*),$$

de sorte que x^* est bien un minimiseur de (P). \square

1.4 Stricte convexité et unicité du minimiseur

Définition 5. Soit $X \subseteq \mathbb{R}^d$ un ensemble convexe. Une fonction $f : X \rightarrow \mathbb{R}$ est strictement convexe si

$$\forall x \neq y \in X, \forall t \in]0, 1[, f((1-t)x + ty) < (1-t)f(x) + tf(y).$$

Proposition 9. Soit $X \subseteq \mathbb{R}^d$ convexe et $f : X \rightarrow \mathbb{R}$ strictement convexe. Alors f admet au plus un minimiseur sur X .

Démonstration. Par l'absurde, supposons que f admette deux minimiseurs distincts $x^* \neq y^* \in \Omega$. Par convexité de Ω , le point $z^* = \frac{1}{2}(x^* + y^*)$ appartient à Ω . Alors, par stricte convexité de la fonction f on a $f(z^*) < \frac{1}{2}(f(x^*) + f(y^*)) = f(x^*)$, ce qui contredit l'hypothèse que x^* minimise f sur Ω . \square

Remarque 4. Cette proposition ne dit rien de l'existence d'un minimiseur.

Chapitre 2

Descente de gradient à pas optimal

On souhaite résoudre numériquement le problème de minimisation d'une fonction $f \in \mathcal{C}^0(\Omega)$ sur un ouvert $\Omega \subseteq \mathbb{R}^d$. Comme en général il n'est pas raisonnable d'espérer calculer de manière exacte un minimiseur ou même la valeur de l'infimum du problème (P), on cherchera à l'*approcher*. Il s'agira de construire une suite $(x^{(k)})_{k \geq 0}$ d'éléments de Ω vérifiant une des deux propriétés suivantes :

- (a) la suite $x^{(k)}$ est minimisante pour (P), i.e. $\lim_{k \rightarrow +\infty} f(x^{(k)}) = \inf_{\Omega} f$.
- (b) la suite $x^{(k)}$ converge vers un minimiseur de f sur Ω .

Dans ce chapitre, nous nous intéresserons à la construction de suites $x^{(k)}$ vérifiant la seconde propriété, qui est bien sûr plus forte que la première .:

2.1 Méthode de descente

Vocabulaire On appelle *méthode de descente* un procédé algorithmique permettant de construire itérativement une suite vérifiant (a) ou (b). Typiquement, une méthode de descente prend la forme suivante

$$\begin{cases} d^{(k)} = \dots & \text{direction de descente} \\ t^{(k)} = \dots & \text{pas de descente} \\ x^{(k+1)} = x^{(k)} + t^{(k)}d^{(k)} \end{cases}$$

Un tel algorithme est appelé méthode de descente si $f(x^{(k+1)}) \leq f(x^{(k)})$. Dans ce cours, on considèrera les possibilités suivantes :

- (a) La *direction de descente* peut être égale à l'opposé du gradient, $d^{(k)} = -\nabla f(x^{(k)})$, auquel cas on parle de méthode de descente de gradient. Lorsque f est \mathcal{C}^2 , il peut être plus avantageux de choisir $d^{(k)} = -D^2 f(x^{(k)})^{-1} \nabla f(x^{(k)})$, auquel cas on parle de méthode de Newton.
- (b) Le *pas de descente* peut être choisi constant ($t^{(k)} = \tau$), optimal (cf (2.2)), ou obtenu par des constructions un peu plus complexes, permettant de garantir la convergence de la méthode.

Définition 6. Soit $f \in \mathcal{C}^0(\Omega)$, $\Omega \subseteq \mathbb{R}^d$ ouvert. On appelle *direction de descente* en $x \in \Omega$ tout vecteur v tel que $\exists \tau > 0, \forall t \in [0, \tau], f(x + tv) < f(x)$.

Exercice 2. Si $f \in \mathcal{C}^1(\Omega)$ et $\langle v | \nabla f(x) \rangle < 0$, alors v est une direction de descente.

Si f est différentiable en x , on a $f(x + tv) = f(x) + \langle \nabla f(x) | v \rangle + o(t)$. On cherche naturellement une direction de descente rendant le produit scalaire $\langle \nabla f(x) | v \rangle$ le plus petit possible, menant au choix de $d^{(k)} = -\nabla f(x^{(k)})$:

Lemme 10. Soit $f \in \mathcal{C}^1(\Omega)$ et $x_0 \in \Omega$. Alors, $\min_{\|v\|=1} d_{x_0} f(v) = -\|\nabla f(x_0)\|$ et si $\nabla f(x_0) \neq 0$, l'unique minimiseur est $v = -\nabla f(x_0) / \|\nabla f(x_0)\|$.

Démonstration. On a $d_x f(v) = \langle \nabla f(x_0) | v \rangle \geq -\|\nabla f(x_0)\| \|v\|$ par Cauchy-Schwarz, avec égalité si et seulement si v est positivement homogène à $-\nabla f(x_0)$. Comme $\|v\| = 1$, on a $v = -\nabla f(x_0) / \|\nabla f(x_0)\|$. \square

2.2 Convexité et hessienne

Définition 7. Soit $f \in \mathcal{C}^2(\Omega)$, où $\Omega \subseteq \mathbb{R}^d$ est un ouvert. On appelle *hessienne* de f en $x_0 \in \Omega$ la matrice des dérivées partielles secondes :

$$D^2 f(x) = \left(\frac{\partial^2 f}{\partial e_i \partial e_j}(x) \right)_{1 \leq i, j \leq d},$$

où l'on a noté $(e_i)_{1 \leq i \leq d}$ la base canonique de \mathbb{R}^d et où

$$\frac{\partial^2 f}{\partial e_i \partial e_j}(x) = \lim_{\varepsilon \rightarrow 0} \frac{1}{\varepsilon} \left(\frac{\partial f}{\partial e_j}(x + \varepsilon e_i) - \frac{\partial f}{\partial e_j}(x) \right).$$

Définition 8. À toute matrice symétrique $A \in \mathcal{M}_{d,d}(\mathbb{R})$ on peut associer une fonction (appelée forme quadratique) $q_A : x \in \mathbb{R}^d \mapsto \langle x | Ax \rangle$.

- (i) Une matrice symétrique A est dite *positive* (ce qu'on note $A \succeq 0$) si et seulement si la forme quadratique associée q_A est positive, i.e.

$$\forall x \in \mathbb{R}^d, \langle x | Ax \rangle \geq 0.$$

- (ii) Une matrice symétrique est dite *définie positive* si

$$\forall x \in \mathbb{R}^d \setminus \{0\}, \langle x | Ax \rangle > 0.$$

- (iii) Soient A, B deux matrices symétriques. On note $A \succeq B$ si et seulement si $A - B \succeq 0$, ou de manière équivalente si $q_A \geq q_B$.

Exemple 3. En particulier, on $\lambda \text{Id} \preceq A \preceq \lambda \text{Id}$ si et seulement si

$$\forall x \in \mathbb{R}^d, \quad \lambda \|x\|^2 \leq \langle x | Ax \rangle \leq \lambda \|x\|^2.$$

Proposition 11. Soit $\Omega \subseteq \mathbb{R}^d$ un ouvert, $X \subseteq \Omega$ convexe et $f \in \mathcal{C}^2(\Omega)$. Si $D^2f(x) \succeq 0, \forall x \in X, D^2f(x) \succeq 0$, alors f est convexe sur X .

Remarque 5. La réciproque est fautive si X n'est pas ouvert.

Lemme 12. Soit $\Omega \subseteq \mathbb{R}^d$ ouvert, $f \in \mathcal{C}^2(\Omega)$, $x \in \Omega$ et $v \in \mathbb{R}^d$ et $g : t \mapsto f(x_t)$ où $x_t = x + tv$. Alors,

$$g''(t) = \langle D^2f(x_t)v|v \rangle. \quad (2.1)$$

Démonstration. Par le lemme 7, $g'(t) = \langle \nabla f(x_t)|v \rangle$, soit en coordonnées

$$g'(t) = \sum_{1 \leq i \leq d} \frac{\partial f}{\partial e_i}(x_t)v_i = \sum_{1 \leq i \leq d} g_i(t)v_i,$$

où l'on a posé $f_i = \frac{\partial f}{\partial e_i}$ et $g_i(t) = f_i(x_t)$. Ainsi, $g''(t) = \sum_i g'_i(t)v_i$. En appliquant le lemme 7 à la fonction g_i on obtient

$$g'_i(t) = \langle \nabla f_i(x_t)|v \rangle = \sum_{1 \leq j \leq d} \frac{\partial g_i}{\partial e_j}(x_t)v_j = \sum_{1 \leq j \leq d} \frac{\partial^2 f}{\partial_j \partial e_i}(x_t)v_j,$$

de sorte que

$$g''(t) = \sum_{1 \leq i, j \leq d} \frac{\partial^2 f}{\partial e_j \partial e_i}(x_t)v_jv_i.$$

D'autre part, par définition de D^2f , les coordonnées du vecteur $D^2f(x_t)v$ sont

$$(D^2f(x_t)v)_i = \sum_{1 \leq j \leq d} \frac{\partial^2 f}{\partial e_i \partial e_j}v_j,$$

$$\text{d'où } \langle D^2f(x_t)v|v \rangle = \sum_{1 \leq i, j \leq d} \frac{\partial^2 f}{\partial e_i \partial e_j}v_jv_i = g''(x_t). \quad \square$$

Démonstration de la proposition 11. Pour la réciproque, nous considérons $x, y \in \Omega$ et $g(t) = f(x_t)$ où $x_t = (1-t)x + ty$. Alors, $g''(t) = \langle D^2f(x_t)(y-x)|y-x \rangle$ est positif par hypothèse, de sorte que

$$g'(1) = g'(0) + \int_0^1 g''(t)dt \geq g'(0),$$

soit $\langle \nabla f(y)|y-x \rangle \geq \langle \nabla f(x)|y-x \rangle$. La proposition 6 montre que f est convexe. \square

2.3 Descente de gradient à pas optimal

Définition 9. Soit $\Omega \subseteq \mathbb{R}^d$ ouvert et $f \in \mathcal{C}^1(\Omega)$. L'algorithme de descente de gradient à pas optimal est donné par :

$$\begin{cases} d^{(k)} = -\nabla f(x^{(k)}) \\ t^{(k)} \in \arg \min_t f(x^{(k)} + td^{(k)}) \\ x^{(k+1)} = x^{(k)} + t^{(k)}d^{(k)} \end{cases} \quad (2.2)$$

Remarque 6. Par construction, les itérées vérifient $f(x^{(k+1)}) \leq f(x^{(k)})$.

Remarque 7. Pour pouvoir mettre en œuvre cet algorithme il faut pouvoir calculer le pas optimal $t^{(k)}$ à chaque itération, ce qui implique de résoudre un problème d'optimisation (sur \mathbb{R}). Ceci n'est faisable de manière exacte que dans un nombre très limité de cas. En général, on préférera d'autre méthode de calcul du pas.

Exemple 4. Soit $f : x \in \mathbb{R}^d \mapsto \frac{1}{2}\langle Qx|x \rangle + \langle b|x \rangle$ où Q est une matrice symétrique définie positive. Alors f est strictement convexe et $\nabla f(x) = Qx + b$. Soit $x^{(k)} \in \mathbb{R}^d$, $d^{(k)} = -\nabla f(x^{(k)})$. Pour calculer le pas $t^{(k)} \in \mathbb{R}$, on cherche le minimum de $g : t \in \mathbb{R} \mapsto f(x_t)$ où $x_t = x^{(k)} + td^{(k)}$. La fonction g est convexe et atteint donc son minimum en l'unique point $t^{(k)}$ vérifiant $g'(t^{(k)}) = 0$. Or, $g'(t) = \langle \nabla f(x_t)|d^{(k)} \rangle$, soit

$$\begin{aligned} g'(t^{(k)}) = 0 &\iff \langle Q(x^{(k)} + t^{(k)}d^{(k)}) + b|d^{(k)} \rangle = 0 \\ &\iff t^{(k)}\langle Qd^{(k)}|d^{(k)} \rangle - \langle d^{(k)}|d^{(k)} \rangle = 0. \end{aligned}$$

Ainsi, $t^{(k)} = \langle d^{(k)}|d^{(k)} \rangle / \langle Qd^{(k)}|d^{(k)} \rangle$. En résumé, dans le cas d'une fonction f de la forme considérée, l'algorithme de descente de gradient à pas optimal s'écrit

$$\begin{cases} d^{(k)} = -(Qx^{(k)} + b) \\ t^{(k)} = \frac{\langle d^{(k)}|d^{(k)} \rangle}{\langle Qd^{(k)}|d^{(k)} \rangle} \\ x^{(k+1)} = x^{(k)} + t^{(k)}d^{(k)}. \end{cases} \quad (2.3)$$

On suppose dans la suite que l'ensemble

$$S = \{x \in \Omega \mid f(x) \leq f(x^{(0)})\} \text{ est compact,} \quad (2.4)$$

ce qui garantit (proposition 2) l'existence d'un minimiseur de f sur Ω .

Lemme 13. *Sous l'hypothèse (2.4), le minimum dans la définition du pas est atteint.*

Démonstration. Il s'agit de démontrer que la fonction $g : t \mapsto f(x^{(k)} + td^{(k)})$ atteint son minimum, et grâce à la proposition 2, il suffit de montrer que le sous-niveau $S_g := \{t \in \mathbb{R} \mid g(t) \leq f(x^{(k)})\}$ est compact. Soit $(t_n)_{n \geq 1}$ une suite d'éléments de l'ensemble S_g . Alors $z_n = x^{(k)} + t_n d^{(k)}$ appartient au compact S (car par hypothèse $f(z_n) \leq f(x^{(k)}) \leq f(x^{(0)})$) et admet donc une sous-suite convergente. On en déduit que t_n possède aussi une sous-suite convergente, montrant la compacité de S_g . \square

Théorème 14. Soit $\Omega \subseteq \mathbb{R}^d$ un ouvert convexe et $f \in \mathcal{C}^2(\Omega)$ vérifiant

- (i) le sous-niveau $S = \{x \in \Omega \mid f(x) \leq f(x^{(0)})\}$ est compact.
- (ii) $\exists M > 0, \forall x \in S, D^2 f(x) \preceq M \text{Id}$,
- (iii) f est strictement convexe,

Alors les itérées de l'algorithme (2.2) convergent vers l'unique minimiseur global de f sur Ω .

On utilisera la proposition suivante :

Proposition 15. Soit $(x_k)_{k \geq 1}$ une suite bornée de \mathbb{R}^d admettant une unique valeur d'adhérence \bar{x} .¹ Alors, $\lim_{k \rightarrow +\infty} x_k = \bar{x}$.

Démonstration du théorème 14. Soit $k \geq 1$ et $g(t) = f(x^{(k)} + td^{(k)}) = f(x^{(k)} - t\nabla f(x^{(k)}))$. Par définition du pas optimal $t^{(k)}$ on a

$$f(x^{(k+1)}) = \min_t f(x^{(k)} + td^{(k)}) \leq \min_t g(t),$$

et nous allons utiliser un développement de Taylor pour estimer le minimum de g . Par le lemme 12, et en posant $x_t = x^{(k)} + td^{(k)}$ on a

$$g'(t) = \langle \nabla g(x_t) | d^{(k)} \rangle, \quad g''(t) = \langle D^2 g(x_t) d^{(k)} | d^{(k)} \rangle.$$

Comme sous-niveau d'une fonction convexe, l'ensemble S est un compact convexe, de sorte que l'ensemble $\sigma = \{t \in \mathbb{R} \mid x_t \in S\}$ est un segment. Par Taylor-Lagrange, pour tout $t \in S$, il existe $s \in [0, t]$ tel que $g(t) = g(0) + tg'(0) + \frac{t^2}{2}g''(s)$. Ainsi,

$$\begin{aligned} g(t) &= g(0) + tg'(0) + \frac{t^2}{2}g''(s) \\ &= f(x^{(k)}) - t \|\nabla f(x^{(k)})\|^2 + \frac{t^2}{2} \langle D^2 g(x_s) \nabla f(x^{(k)}) | \nabla f(x^{(k)}) \rangle \\ &\leq f(x^{(k)}) + \left(\frac{M}{2}t^2 - t \right) \|\nabla f(x^{(k)})\|^2, \end{aligned}$$

où l'on a utilisé l'hypothèse (ii) pour passer de la deuxième à la troisième ligne. Le minimum de ce second membre est atteint en $t = 1/M$ et on a donc

$$f(x^{(k+1)}) \leq \min_t g(t) \leq f(x^{(k)}) - \frac{1}{2M} \|\nabla f(x^{(k)})\|^2,$$

de sorte que

$$\|\nabla f(x^{(k)})\|^2 \leq 2M(f(x^{(k)}) - f(x^{(k+1)})). \quad (2.5)$$

Ainsi, pour tout $K \geq 0$ on a

$$\sum_{0 \leq k \leq K} \|\nabla f(x^{(k)})\|^2 \leq 2M(f(x^{(0)}) - f(x^{(K)})) \leq 2M(f(x^{(0)}) - \inf_{\Omega} f).$$

1. On rappelle que \bar{x} est valeur d'adhérence de la suite $(x_k)_{k \geq 1}$ si et seulement si il existe une suite extraite $(x_{\sigma(k)})_{k \geq 1}$ dont la limite est \bar{x}

La série de terme général $\|\nabla f(x^{(k)})\|^2$ est donc convergente, d'où l'on déduit que $\lim_{k \rightarrow +\infty} \|\nabla f(x^{(k)})\| = 0$.

Montrons enfin que $\lim_{k \rightarrow +\infty} x^{(k)} = x^*$, où x^* est l'unique minimum de f sur Ω , l'unicité provenant de la stricte convexité de f et de la proposition 9. Comme $f(x^{(k)}) \leq f(x^{(0)})$, le point $x^{(k)}$ appartient à S , qui est par hypothèse compact donc borné. Pour montrer que la suite $x^{(k)}$ converge vers x^* , il suffit par la proposition 15 de démontrer qu'elle admet x^* pour seule valeur d'adhérence. Soit donc $(x^{(\sigma(k))})$ une sous-suite convergeant vers une valeur d'adhérence $\bar{x} \in S$. Alors, comme $f \in \mathcal{C}^1(\Omega)$, $\nabla f(\bar{x}) = \lim_{k \rightarrow +\infty} \nabla f(x^{(\sigma(k))}) = 0$. Par convexité (théorème 8), on sait que \bar{x} est un minimiseur de f sur Ω . Par unicité du minimiseur, on en déduit que $\bar{x} = x^*$. \square

Chapitre 3

Descente de gradient à pas optimal II

3.1 Forte convexité et stabilité du minimum

Motivation. Soit $\Omega \subseteq \mathbb{R}^d$ un ouvert convexe $f \in \mathcal{C}^0(X)$ atteignant son minimum x^* sur Ω . On a vu dans la proposition 9 que si f est strictement convexe, alors f admet au plus un minimiseur x^* sur X . Une manière de reformuler cette propriété est la suivante :

$$(x \in \Omega \text{ et } f(x) \leq f(x^*)) \implies x = x^*.$$

En pratique, nos algorithmes sont incapables de calculer x^* mais permettent au mieux de calculer une suite $x^{(k)}$ tel que $f(x^{(k)}) \leq f(x^*) + \varepsilon_k$ où $\lim_{k \rightarrow +\infty} \varepsilon_k = 0$. On aimerait pouvoir en déduire que $x^{(k)}$ est “proche” de la solution x^* , i.e. $\|x^{(k)} - x^*\| \leq C\varepsilon_k^\alpha$ pour un certain exposant $\alpha > 0$ et une constante $C > 0$. Nous verrons qu’une telle inégalité est vraie pour $\alpha = \frac{1}{2}$ si la fonction f est *fortement convexe*.

Définition 10. Soit $X \subseteq \mathbb{R}^d$ un ensemble convexe. Une fonction $f : X \rightarrow \mathbb{R}$ est dite *m-fortement convexe* sur X , où $m > 0$ si la fonction $f - \frac{m}{2} \|\cdot\|^2$ est convexe.

Exercice 3. Si f est *m-fortement convexe*, alors elle est aussi strictement convexe.

Proposition 16. Soit Ω un ouvert de \mathbb{R}^d , $f \in \mathcal{C}^1(\Omega)$ et $X \subseteq \Omega$ convexe. Les propositions suivantes sont équivalentes :

- (i) f est *m-fortement convexe* sur X ;
 - (ii) $\forall x, y \in X, \quad f(y) \geq f(x) + \langle \nabla f(x) | y - x \rangle + \frac{m}{2} \|x - y\|^2$
 - (iii) $\forall x, y \in X, \quad \langle \nabla f(y) - \nabla f(x) | y - x \rangle \geq m \|x - y\|^2$
- De plus, si $f \in \mathcal{C}^2(\Omega)$ et si $\forall x \in \Omega, \quad D^2f(x) \succeq m\text{Id}$, alors f est *m-fortement convexe* sur X .

Démonstration. La fonction f est m -fortement convexe si et seulement si la fonction $g = f - \frac{m}{2} \|\cdot\|^2$ est convexe. L'équivalence est s'obtient et utilisant les proposition 6 11 pour caractériser la convexité de g . \square

Exemple 5. La fonction $f : t \mapsto \exp(t)$ n'est pas fortement convexe sur \mathbb{R} (car $f'' = \exp(t)$ n'est pas minoré sur \mathbb{R}), mais elle est m -fortement convexe sur tout segment $[a, b]$ pour $m = \min_{t \in [a, b]} \exp(t)$. De même, fonction $t \mapsto t^4$ n'est pas fortement convexe sur \mathbb{R} mais est fortement convexe sur tout segment ne contenant pas l'origine.

Corollaire 17. Soit $\Omega \subseteq \mathbb{R}^d$ un ouvert convexe, $f \in \mathcal{C}^1(\Omega)$ une fonction m -fortement convexe et x^* un minimiseur de f sur Ω . Alors, pour tout $x \in \Omega$,

- (i) $\|x - x^*\|^2 \leq \frac{2}{m}(f(x) - f(x^*))$
- (ii) $\|x - x^*\| \leq \frac{1}{m} \|\nabla f(x)\|$
- (iii) $f(x) - f(x^*) \leq \frac{1}{2m} \|\nabla f(x)\|^2$

Remarque 8. Le point (i) montre immédiatement que le minimiseur de f est unique : si x est un autre minimiseur, on a $f(x) = f(x^*)$, de sorte que par (i), $x = x^*$. Mais il faut surtout retenir que si x est "presqu'un minimiseur", au sens où $f(x) \leq f(x^*) + \varepsilon$, alors x est "proche" du minimiseur x^* , plus précisément $\|x - x^*\| \leq \sqrt{2\varepsilon/m}$. On tire des conclusions similaires du point (ii) : si la condition d'optimalité ($\nabla f(x^*) = 0$) est "presque vérifiée", i.e. si $\|\nabla f(x)\| \leq \varepsilon$ est petit, alors $\|x - x^*\| \leq \varepsilon/m$.

Exemple 6. Pour $f(t) = t^4$, on a $x^* = 0$ et l'inégalité (i), qui s'écrit $t^2 \leq \frac{2}{m}t^4$, n'est vraie pour aucun $m > 0$.

Démonstration. (i) est une conséquence immédiate de la formulation équivalente de la forte convexité donnée dans la proposition 16.(ii) :

$$f(x) \geq f(x^*) + \langle x - x^* | \nabla f(x^*) \rangle + \frac{m}{2} \|x - x^*\|^2 = f(x^*) + \frac{m}{2} \|x - x^*\|^2,$$

où l'on a utilisé $\nabla f(x^*) = 0$ par optimalité de x^* . (ii) s'obtient de la même manière, en utilisant proposition 16.(iii).

(iii) Par l'inégalité (ii) de la proposition 16, on a pour tout $x, y \in \Omega$

$$f(y) \geq Q(x, y) := f(x) + \langle y - x | \nabla f(x) \rangle + \frac{m}{2} \|y - x\|^2.$$

Ainsi, $f(y) \geq \inf_z g(z)$ où $g(z) = Q(x, z)$. Comme g est convexe sur \mathbb{R}^d , son unique minimiseur z^* est solution de l'équation

$$\nabla g(z^*) = 0 = \nabla f(x) + m(z^* - x),$$

c'est-à-dire que $z^* = x - \frac{1}{m} \nabla f(x)$. Ainsi, nous venons de démontrer que

$$\forall y \in \Omega, f(y) \geq g(z^*) = f(x) - \frac{1}{m} \|\nabla f(x)\|^2 + \frac{m}{2} \left\| \frac{1}{m} \nabla f(x) \right\|^2 = f(x) - \frac{1}{2m} \|\nabla f(x)\|^2.$$

En prenant $y = x^*$ dans l'inégalité précédente, on obtient le résultat voulu. \square

3.2 Vitesse de convergence du gradient à pas optimal

Définition 11 (Vitesse de convergence). Soit $(u_k)_{k \geq 0}$ une suite de limite u^* . On dira que la suite (u_k) converge *linéairement* vers u^* s'il existe $\kappa < 1$ et $k_0 \in \mathbb{N}$ telle que

$$\forall k \geq k_0, \|u_{k+1} - u^*\| \leq \kappa \|u_k - u^*\|.$$

On dira que la suite (u_k) converge *quadratiquement* vers u^* s'il existe $\gamma > 0$ telle que

$$\|u_{k+1} - u^*\| \leq \gamma \|u_k - u^*\|^2.$$

Théorème 18. Soit $\Omega \subseteq \mathbb{R}^d$ un ouvert convexe et $f \in \mathcal{C}^2(\Omega)$ vérifiant

- (i) le sous-niveau $S = \{x \in \Omega \mid f(x) \leq f(x^{(0)})\}$ est compact.
 - (ii) $\exists M, \forall x \in S, D^2 f(x) \preceq M \text{Id}$,
 - (iii) $\exists m > 0, \forall x \in S, D^2 f(x) \succeq m \text{Id}$,
- Alors les itérées de l'algorithme (2.2) convergent vers l'unique minimiseur global de f sur Ω , et de plus, en posant $c = M/m$,

$$f(x^{(k+1)}) - f(x^*) \leq \left(1 - \frac{1}{c}\right) \left(f(x^{(k)}) - f(x^*)\right). \quad (3.1)$$

Remarque 9. En d'autres termes, $(f(x^{(k)}))_{k \geq 0}$ converge linéairement vers $f(x^*)$.

Remarque 10. Si une fonction $f \in \mathcal{C}^2(\Omega)$, vérifie $m \text{Id} \preceq D^2 f(x) \preceq M \text{Id}$, on pourra dire que le *conditionnement* de f est majoré par $c = \frac{M}{m}$. L'inégalité (3.1) montre que cette quantité est cruciale pour comprendre la vitesse de convergence de l'algorithme de descente de gradient. Par exemple, si l'on souhaite estimer $f(x^*)$ à $\varepsilon > 0$ près, d'après l'inégalité (3.1), il suffit d'interrompre l'algorithme de descente de gradient à pas optimal après k itérations où

$$\left(1 - \frac{1}{c}\right)^k (f(x^{(0)}) - f(x^*)) \leq \varepsilon,$$

soit

$$k \geq \frac{\log\left(\frac{f(x^{(0)}) - f(x^*)}{\varepsilon}\right)}{\log\left(\frac{1}{1-1/c}\right)} \sim_{c \rightarrow +\infty} c \log\left(\frac{f(x^{(0)}) - f(x^*)}{\varepsilon}\right)$$

Ainsi, dans le cas $c \gg 1$, le nombre d'itération est *proportionnel* au conditionnement !

Démonstration du théorème 18. Le corollaire (17) nous donne

$$f(x^k) - f(x^*) \leq \frac{1}{2m} \left\| \nabla f(x^{(k)}) \right\|^2.$$

En combinant avec l'inégalité (2.5), on obtient

$$2m(f(x^k) - f(x^*)) \leq \left\| \nabla f(x^{(k)}) \right\|^2 \leq 2M(f(x^{(k)}) - f(x^{(k+1)})),$$

de sorte qu'en posant $c = M/m$, on obtient bien l'inégalité voulue. \square

3.3 Une condition suffisante pour la forte convexité

Proposition 19. *Soit $\Omega \subseteq \mathbb{R}^d$ un ouvert convexe, $f \in \mathcal{C}^2(\Omega)$ et $S \subseteq \Omega$ compact tel que $\forall x \in S$, $D^2f(x)$ est définie positive. Alors $\exists M \geq m > 0$ tels que*

$$\forall x \in S, m\text{Id} \leq D^2f(x) \leq M\text{Id}.$$

Démonstration. L'ensemble $K = \{(x, v) \in S \times \mathbb{R}^d \mid \|v\| = 1\}$ est compact comme fermé borné. La fonction la fonction $(x, v) \in K \times K \mapsto \langle D^2f(x)v|v \rangle$ est continue et donc bornée sur K , par exemple

$$\forall (x, v) \in K, m \leq \langle D^2f(x)v|v \rangle \leq M.$$

De plus la fonction atteint ses bornes sur K : il existe donc $(x_0, v_0) \in K$ tels que $m = \langle D^2f(x_0)v_0|v_0 \rangle > 0$ par hypothèses et comme $v_0 \neq 0$ (car $\|v_0\| = 1$). On en déduit l'inégalité voulue en remarquant que

$$\forall w \in \mathbb{R}^d, \langle D^2f(x)w|w \rangle = \langle D^2f(x) \frac{w}{\|w\|} | \frac{w}{\|w\|} \rangle \|w\|^2,$$

de sorte que $m \|w\|^2 \leq \langle D^2f(x)w|w \rangle \leq M \|w\|^2$ comme souhaité. \square

Cette proposition permet d'énoncer une variante non-quantitative du théorème 18

Corollaire 20. *Soit $\Omega \subseteq \mathbb{R}^d$ un ouvert convexe et $f \in \mathcal{C}^2(\Omega)$ vérifiant*

- (i) *le sous-niveau $S = \{x \in \Omega \mid f(x) \leq f(x^{(0)})\}$ est compact,*
- (ii) *$\forall x \in S$, $D^2f(x)$ est définie positive.*

Alors les itérées de l'algorithme (2.2) convergent vers l'unique minimiseur global x^ de f sur Ω , et de plus $(f(x^{(k)}))_{k \geq 0}$ converge linéairement vers $f(x^*)$.*

Exemple 7. Soit a_1, \dots, a_N une famille de vecteurs non nuls de \mathbb{R}^d et

$$f(x) = - \sum_{1 \leq \alpha \leq N} \log(1 - \langle x|a_\alpha \rangle).$$

On fait les deux hypothèses¹ sur la famille $(a_\alpha)_{1 \leq \alpha \leq N}$, qui sont par exemple vérifiées par le choix de $a_1 = (1, 0)$, $a_2 = (-1, 0)$, $a_3 = (0, 1)$, $a_4 = (0, -1)$ dans \mathbb{R}^2 :

- la famille est positivement génératrice, i.e. tout point de \mathbb{R}^d peut s'écrire sous la forme $x = \sum_\alpha \lambda_\alpha a_\alpha$, avec $\lambda_\alpha \geq 0$.
- l'ensemble $K = \{x \in \mathbb{R}^d \mid \forall \alpha \in \{1, \dots, N\}, \langle x|a_\alpha \rangle \leq 1\}$ est compact.

1. La première hypothèse implique en fait la seconde. En effet, pour tout $v \in \{\pm e_i \mid 1 \leq i \leq d\}$, il existe $(\lambda_\alpha)_{1 \leq \alpha \leq N}$ positifs tels que $v = \sum_\alpha \lambda_\alpha a_\alpha$. Ainsi $\langle x|v \rangle = \sum_\alpha \lambda_\alpha \langle x|a_\alpha \rangle \leq \sum_i \lambda_i$ pour tout $x \in K$. On en déduit que K est bornée pour la norme $\|\cdot\|_\infty$ (exercice) et donc compact.

Nous allons appliquer le corollaire précédente pour démontrer la convergence de l'algorithme de descente de gradient à pas optimal partant d'un point quelconque $x^{(0)} \in \Omega$. On remarque d'abord que la fonction f est de classe \mathcal{C}^∞ sur son ensemble de définition $\Omega = \{x \in \mathbb{R}^d \mid \forall \alpha, \langle x | a_\alpha \rangle < 1\}$, qui est un ouvert convexe (exercice). Commençons par démontrer la propriété (ii). Soit $x \in \Omega$, $v \in \mathbb{R}^d$ et $g(t) = f(x_t)$ où $x_t = x + tv$. Alors,

$$g'(t) = \langle \nabla f(x_t) | v \rangle = \sum_{1 \leq \alpha \leq N} \frac{\langle a_\alpha | v \rangle}{1 - \langle x_t | a_\alpha \rangle}$$

$$g''(t) = \langle D^2 f(x_t) v | v \rangle = \sum_{1 \leq \alpha \leq N} \frac{\langle a_\alpha | v \rangle^2}{(1 - \langle x_t | a_\alpha \rangle)^2}$$

Ainsi, pour tout $(x, v) \in \Omega \times \mathbb{R}^d$, $\langle D^2 f(x) v | v \rangle \geq 0$ et la fonction f est donc bien convexe. Montrons maintenant que $D^2 f(x)$ est définie positive. Soit $v \in \mathbb{R}^d$ tel que $\langle D^2 f(x) v | v \rangle = 0$. Alors, $\forall \alpha, \langle a_\alpha | v \rangle = 0$ et comme la famille $(a_\alpha)_{\alpha \in A}$ est génératrice, on doit donc avoir $v = 0$.

Il nous reste à démontrer que le sous-niveau $S = \{x \in \Omega \mid f(x) \leq f(x^{(0)})\}$ est compact, ce qui se déduit de la continuité de f et de la compacité de K .

Chapitre 4

Descente avec pas d'Armijo

Une des objections à l'algorithme de descente de gradient à pas optimal est le calcul du pas demande de résoudre un problème d'optimisation 1D à chaque itération. Nous verrons dans ce chapitre une manière simple de choisir le pas qui donne les mêmes garanties de convergence. Nous allons également un peu relaxer l'hypothèse que $d^{(k)} = -\nabla f(x^{(k)})$ afin de préparer le terrain à l'analyse de l'algorithme de Newton dans le chapitre suivant. Nous supposons donc que la direction de descente est définie de la manière suivante, où $B^{(k)}$ est une matrice symétrique définie positive

$$d^{(k)} = -B^{(k)}\nabla f(x^{(k)}) \quad (4.1)$$

Le fait que $B^{(k)}$ est symétrique définie positive garantit que $\langle d^{(k)} | \nabla f(x^{(k)}) \rangle < 0$, i.e. que $d^{(k)}$ est bien une direction de descente.

Remarque 11. Une méthode de descente où la direction $d^{(k)}$ est définie par la relation (4.1) est souvent appelé *descente de gradient préconditionné*, et la matrice $B^{(k)}$ est appelée *préconditionneur*.

4.1 Choix du pas par rebroussement

4.1.1 Rebroussement naïf

Comme nous souhaitons construire une méthode de descente, il serait assez naturel de considérer le pas suivant,

$$t^{(k)} = \max\{t \geq 0 \mid \exists \ell \in \mathbb{N}, t = 2^{-\ell} \text{ et } f(x^{(k)} + td^{(k)}) \leq f(x^{(k)})\}.$$

Autrement dit étant donné $x^{(k)}, d^{(k)}$ on teste les pas de $1, \frac{1}{2}, \frac{1}{4}, \dots, \frac{1}{2^\ell}$ et on s'arrête dès que la condition de descente $f(x^{(k)} + 2^{-\ell}d^{(k)}) \leq f(x^{(k)})$ est satisfaite. Cet algorithme, assez naturel, est en fait non-convergent en général. Considérons $f(x) = x^2$ sur \mathbb{R} et $x^{(0)} = 1, d^{(k)} = -f'(x^{(k)}) = -2x^{(k)}$. Alors le pas $t^{(k)} = 1$ est admissible et on obtient donc $x^{(k)} = (-1)^k$ qui ne converge pas vers le minimum de f sur Ω .

4.1.2 Rebroussement d'Armijo

L'idée est de renforcer la condition de descente $f(x^{(k)} + t^{(k)}d^{(k)}) \leq f(x^{(k)})$ par la condition plus forte (4.2) appelée "condition d'Armijo" :

Lemme 21. Soit $f \in \mathcal{C}^1(\Omega)$, $\Omega \subseteq \mathbb{R}^d$ ouvert, $v \in \mathbb{R}^d$ tel que $\langle \nabla f(x)|v \rangle < 0$, et $0 < \alpha < \frac{1}{2}$. Alors, il existe $t_0 > 0$ tel que $\forall t \in [0, t_0]$,

$$f(x + tv) \leq f(x) + \alpha t \langle \nabla f(x)|v \rangle. \quad (4.2)$$

Démonstration. C'est une conséquence immédiate de l'égalité

$$f(x + tv) = f(x) + \alpha t \langle \nabla f(x)|v \rangle + (1 - \alpha)t \langle \nabla f(x)|v \rangle + o(t). \quad \square$$

Définition 12 (Pas d'Armijo). Soit $f \in \mathcal{C}^1(\Omega)$, Ω ouvert convexe. Étant donné $x^{(k)}$, $d^{(k)}$ on appellera *pas d'Armijo* de paramètres $0 < \alpha < \frac{1}{2}$ et $0 < \beta < 1$ le pas $t^{(k)}$ défini par

$$t^{(k)} = \max\{t \mid \ell \in \mathbb{N}, t = \beta^\ell, x^{(k)} + td^{(k)} \in \Omega, f(x^{(k)} + td^{(k)}) \leq f(x^{(k)}) + t\alpha \langle \nabla f(x^{(k)})|d^{(k)} \rangle\} \quad (4.3)$$

Remarque 12. En d'autres termes, le pas d'Armijo peut être calculé par la procédure

```

pas_armijo(x(k), d(k)) :
    t ← 1
    tant que f(x(k) + td(k)) > f(x(k)) + tα⟨∇f(x(k))|d(k)⟩ :
        t ← βt
    retourner t
    
```

Pour écrire cet algorithme, on a supposé que lorsque x n'appartient pas au domaine de définition Ω de f alors $f(x) = +\infty$. Ceci qui garantit que si un pas t vérifie le critère d'Armijo

$$f(x^{(k)} + td^{(k)}) \leq f(x^{(k)}) + t\alpha \langle \nabla f(x^{(k)})|d^{(k)} \rangle$$

alors *automatiquement*, $x^{(k)} + td^{(k)} \in \Omega$, et il n'est donc pas nécessaire de tester cette condition. Cette convention est très utile en pratique : il faudra toujours faire en sorte que la fonction Python évaluant la valeur $f(x)$ retourne **Inf** lorsque $x \notin \Omega$.

Définition 13 (Méthode de descente avec pas d'Armijo). On appelle algorithme de descente de gradient préconditionné la méthode itérative suivante, où pour tout $k \in \mathbb{N}$, $B^{(k)} = A^{(k)}A^{(k)}$ et $A^{(k)}$ est une matrices symétriques définies positives :

$$\begin{cases} d^{(k)} = -B^{(k)}\nabla f(x^{(k)}) \\ t^{(k)} = \text{donné par (4.3)} \\ x^{(k)} = x^{(k)} + t^{(k)}d^{(k)}. \end{cases}$$

4.1.3 Convergence de l'algorithme de descente de gradient préconditionné à rebroussement

Théorème 22. Soit $\Omega \subseteq \mathbb{R}^d$ un ouvert convexe et $f \in \mathcal{C}^2(\Omega)$ vérifiant
 (i) le sous-niveau $S = \{x \in \Omega \mid f(x) \leq f(x^{(0)})\}$ est compact.
 (ii) $\exists 0 < \lambda < \Lambda, \forall x \in S, \forall k \in \mathbb{N}, \lambda \text{Id} \leq A^{(k)} \text{D}^2 f(x) A^{(k)} \leq \Lambda \text{Id}$,
 Alors les itérées $x^{(k)}$ de l'algorithme de descente avec pas d'Armijo (Déf. 13) convergent vers l'unique minimiseur global de f sur Ω , et de plus, en posant $c = 2\alpha\lambda \min(1, \beta/\Lambda)$,

$$f(x^{(k+1)}) - f(x^*) \leq (1 - c) \left(f(x^{(k)}) - f(x^*) \right). \quad (4.4)$$

Remarque 13. Cette analyse suggère une manière simple d'améliorer l'algorithme de descente de gradient : il suffit de choisir $B^{(k)}$ tel que le conditionnement Λ/λ soit aussi proche de 1 que possible. Dans le cas $f(x_1, x_2) = Kx_1^2 + x_2^2$, dont la hessienne est $H = \text{diag}(K, 1)$ (constante), l'idéal est bien sûr de prendre $B = A^2$ où $A = \text{diag}(K^{-1/2}, 1)$, soit $B = H^{-1}$. Plus généralement, le choix $B^{(k)} = \text{D}^2 f(x^{(k)})^{-1}$ est souvent judicieux : il donne ce qu'on appelle la "méthode de Newton".

Lemme 23. Soit $f \in \mathcal{C}^2(\Omega)$ et $B^{(k)} = (A^{(k)})^2$ telles que que

$$\forall x \in S, A^{(k)} \text{D}^2 f(x) A^{(k)} \leq \Lambda \text{Id}.$$

Alors, le pas d'Armijo défini par (4.3) vérifie

$$t^{(k)} \geq \min \left(1, \frac{\beta}{\Lambda} \right).$$

Remarque 14. Cette inégalité permet de dire que l'algorithme `pas_armijo` calculant le pas d'Armijo termine dès que $\beta^k \leq \beta/\Lambda$. En d'autres termes, le nombre d'itération de l'algorithme de recherche du pas est au plus $\log(\Lambda/\beta)/\log(1/\beta)$.

Démonstration. Étant donné $t \in \mathbb{R}$, on pose $x_t = x^{(k)} + td^{(k)}$. Si t est tel que $x_t \in S$, alors le segment $[x_0, x_t]$ est inclus dans S et on montre donc comme dans la preuve du théorème 14 que

$$f(x_t) = f(x^{(k)}) + t \langle \nabla f(x^{(k)}) | d^{(k)} \rangle + \frac{t^2}{2} \langle \text{D}^2 f(x_s) d^{(k)} | d^{(k)} \rangle$$

Par (4.1), on a $d^{(k)} = -B^{(k)} \nabla f(x^{(k)}) = -A^2 \nabla f(x^{(k)})$ où on a noté $A = A^{(k)}$. Ainsi,

$$\begin{aligned} \langle \text{D}^2 f(x_s) d^{(k)} | d^{(k)} \rangle &= \langle \text{D}^2 f(x_s) A^2 \nabla f(x^{(k)}) | A^2 \nabla f(x^{(k)}) \rangle \\ &= \langle A \text{D}^2 f(x_s) A (A \nabla f(x^{(k)})) | A \nabla f(x^{(k)}) \rangle \\ &\leq \Lambda \left\| A \nabla f(x^{(k)}) \right\|^2 = \Lambda \langle A^2 \nabla f(x^{(k)}) | \nabla f(x^{(k)}) \rangle = -\langle \nabla f(x^{(k)}) | d^{(k)} \rangle \end{aligned}$$

de sorte que

$$f(x_t) \leq f(x^{(k)}) + (1 - \frac{\Lambda}{2}t)t \langle \nabla f(x^{(k)}) | d^{(k)} \rangle.$$

Ainsi, la condition d'Armijo

$$f(x_t) \leq f(x^{(k)}) + \alpha t \langle \nabla f(x^{(k)}) | d^{(k)} \rangle$$

est vérifiée dès que $1 - \frac{\Lambda}{2}t \geq \alpha$. Comme $\alpha \leq \frac{1}{2}$, il suffit pour cela que $t \leq \Lambda$. \square

Lemme 24. Soit $X \subseteq \Omega \subseteq \mathbb{R}^d$ avec X convexe et Ω ouvert. Soit $f \in \mathcal{C}^2(\Omega)$ et A une matrice symétrique vérifiant $\forall x \in X, AD^2f(x)A \geq \lambda \text{Id}$. Alors

$$2\lambda(f(x) - f(x^*)) \leq \|A\nabla f(x)\|^2.$$

Démonstration. On considère $g(x) = f(Ax)$. Alors $\nabla g(x) = A\nabla f(x)$ et $D^2g(x) = AD^2f(x)A$. On a supposé $AD^2f(x)A \geq \lambda \text{Id}$, et par le corollaire (17) on a

$$2\lambda(g(y) - g(y^*)) \leq \|\nabla g(y)\|^2,$$

où $y^* = Ax^*$. Ainsi, en posant $y = Ax$, $2\lambda(f(x) - f(x^*)) \leq \|A\nabla f(x)\|^2$. \square

Démonstration du théorème 22. Par définition du pas d'Armijo, on sait que

$$\begin{aligned} f(x^{(k+1)}) &\leq f(x^{(k)}) + \alpha t^{(k)} \langle \nabla f(x^{(k)}) | d^{(k)} \rangle \\ &= f(x^{(k)}) - \alpha t^{(k)} \langle \nabla f(x^{(k)}) | B^{(k)} \nabla f(x^{(k)}) \rangle \\ &= f(x^{(k)}) - \alpha t^{(k)} \langle A^{(k)} \nabla f(x^{(k)}) | A^{(k)} \nabla f(x^{(k)}) \rangle \\ &\leq f(x^{(k)}) - \varepsilon \left\| A^{(k)} \nabla f(x^{(k)}) \right\|^2 \quad \text{où } \varepsilon = \alpha \min(1, \beta/\Lambda) \end{aligned}$$

où on a utilisé le lemme 23 pour minorer $t^{(k)}$. En combinant avec le lemme précédent on obtient

$$\begin{aligned} f(x^{(k+1)}) &\leq f(x^{(k)}) - 2\lambda\varepsilon(f(x^{(k)}) - f(x^*)) \\ f(x^{(k+1)}) - f(x^*) &\leq (1 - c)(f(x^{(k)}) - f(x^*)) \quad \text{où } c = 2\lambda\varepsilon. \end{aligned} \quad \square$$